

La régression logistique

Myriam Maumy¹

¹IRMA, Université Louis Pasteur
Strasbourg, France

Master 2ème Année 28-11-2005

Ce cours se base sur l'ouvrage de Bruno Falissard *Comprendre et utiliser les statistiques dans les sciences de la vie*, Professeur des universités et praticien hospitalier à la faculté de médecine Paris-Sud, et le syllabus de *Biostatistique* de Philippe Lambert, Professeur, Université catholique de Louvain.

Exemple

Nombre de souris développant une tumeur au poumon après exposition à la fumée de cigarettes (Essenbergs, Science, 1952).

Groupe	Tumeur présente	Tumeur absente	Total
Contrôle	19	13	32
Traitement	21	2	23

Question : *Existe-t-il une corrélation entre le développement de la maladie et l'apparition du cancer ?*

- Pour **tester** l'existence de ce lien il serait possible de procéder à un test du khi-deux :

Les dénombrements attendus sont imprimés sous les dénombrements observés

	Succès	Echec	Total
1	21 16,73	2 6,27	23
2	19 23,27	13 8,73	32

Total	40	15	55
-------	----	----	----

$$\text{Khi deux} = 1,091 + 2,910 + 0,784 + 2,092 = 6,878$$

$$\text{DL} = 1, P = 0,009$$

Ce test ne permet pas de déterminer la **nature** de ce lien, c'est-à-dire comment sont liées les variations des deux variables.

- **Pour parer à cet inconvénient** : On utilise *la régression logistique* qui permet de **modéliser** la probabilité de succès à l'aide des variables explicatives dont nous disposons. Ceci nous permettra de tester si ces changements sont significatif à un niveau α donné.

De même que la régression linéaire (simple ou multiple) est un prolongement de l'étude du coefficient de corrélation de deux variables, de même la régression logistique est une généralisation d'un coefficient servant à évaluer la corrélation de deux variables qualitatives : *le rapport des côtes* ou *odds-ratio*.

Definition

On appelle **cote du succès** le rapport

$$\exp(\theta) = \frac{\pi}{1 - \pi}$$

où π est la probabilité de succès.

La probabilité de succès s'exprime à partir de la cote de succès de la manière suivante :

$$\pi = \frac{\exp(\theta)}{1 + \exp(\theta)}.$$

Pour fixer les idées voici quelques valeurs de la cote du succès en fonction la probabilité de succès. (Le logarithme de) cette cote :

- est $(< 0) < 1$ lorsque $\pi < 0.5$.
- est $(= 0) = 1$ lorsque $\pi = 0.5$.
- est $(> 0) > 1$ lorsque $\pi > 0.5$.
- $(\rightarrow -\infty) \rightarrow 0$ lorsque $\pi \rightarrow 0$.
- $(\rightarrow +\infty) \rightarrow +\infty$ lorsque $\pi \rightarrow 1$.

Exemple

La probabilité de succès (i.e. celle de développer une tumeur) observée est égale à :

$$\hat{\pi} = \frac{40}{55} = 0.73$$

↓

$$\exp(\hat{\theta}) = \frac{\hat{\pi}}{1 - \hat{\pi}} = 2.67$$

↓

$$\hat{\theta} = 0.98.$$

Le logarithme du rapport de cotes :

- On peut calculer la cote de succès dans différentes conditions. Le *rapport de cotes* Ψ permet alors d'évaluer l'influence du facteur considéré :

$$\Psi = \frac{\exp(\theta_2)}{\exp(\theta_1)} = \exp(\theta_2 - \theta_1).$$

Lorsque Ψ est > 1 (< 1) le succès a une cote supérieure (inférieure) pour le deuxième niveau du facteur.

- Le *logarithme du rapport de cotes*, $\theta_2 - \theta_1$, est > 0 (< 0) lorsque le succès a une probabilité supérieure (inférieure) pour le deuxième niveau du facteur.

Exemple

La cote du succès (= “développer une tumeur”) observée est égale à :

$$\begin{cases} \text{Cote}(\text{succès}/\text{exposé}) = \exp(\hat{\theta}_2) = \frac{21}{19} = 10.5 \\ \text{Cote}(\text{succès}/\text{contrôle}) = \exp(\hat{\theta}_1) = \frac{2}{13} = 1.46 \end{cases}$$

$$\text{d'où } \hat{\psi} = \frac{21 \cdot 13}{19 \cdot 2} = 7.18 > 1$$

$$\text{et } \log(\hat{\psi}) = \hat{\theta}_2 - \hat{\theta}_1 = 1.97 > 0.$$

La cote de succès de la tumeur est supérieure (multipliée par 7) lorsque les souris sont exposées à la fumée de cigarettes.

Intervalle de confiance

- Si pour chaque individu, la probabilité de succès est π , alors, le nombre Y de succès parmi n individus indépendants suit une loi binomiale $\mathcal{B}(n, \pi)$. Ainsi :

$$\begin{aligned} \mathbb{E}[Y] &= n\pi & ; & & \text{Var}[Y] &= n\pi(1 - \pi) \\ \mathbb{E}\left(\hat{\pi} = \frac{Y}{n}\right) &= \frac{1}{n}\mathbb{E}[Y] = \pi & ; & & \text{Var}\left[\hat{\pi} = \frac{Y}{n}\right] &= \frac{1}{n^2}\text{Var}[Y] = \frac{\pi(1 - \pi)}{n} \end{aligned}$$

- Un intervalle de confiance (dans le cadre d'application de l'approximation de la loi binomiale par une loi normale) à 95 % pour π est donné par :

$$\hat{\pi} \pm 1.96 \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n}}$$

- Dans notre exemple on souhaiterait comparer les probabilités π_1 et π_2 de développer une tumeur sous et sans exposition à la fumée de cigarette et déterminer si elles sont significativement différentes. Cela reviendrait à déterminer s'il existe un lien entre le développement de la tumeur et le facteur risque considéré.
- On peut déjà répondre à cette question en construisant un intervalle de confiance à 95 % pour $\pi_1 - \pi_2$.

$$(\hat{\pi}_1 - \hat{\pi}_2) \pm 1.96 \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}}.$$

Exemple

$$0 \notin (0.114, 0.524)$$

On en déduit que la différence $\pi_1 - \pi_2$ est significativement écartée de 0 au seuil $\alpha = 5\%$. Ainsi on sait non seulement la fumée de cigarette a un effet significatif sur le nombre de cancer développés mais on a quantifié cet effet.

- Dans des situations plus complexes (plus de deux variables ou de deux niveaux du facteur) l'approche précédente est trop lourde. On travaille alors avec les cotes de succès.
- Si X est une variable explicative à K niveaux, le modèle logistique suppose que :

$$(Y|X = x_k) \sim \mathcal{B}(n_k, \pi_k)$$

avec

$$\text{logit}(\pi_k) = \log\left(\frac{\pi_k}{1 - \pi_k}\right) = \theta_k = \mu + \alpha_k; (\alpha_1 = 0)$$

$$\Rightarrow \pi_k = \frac{\exp(\mu + \alpha_k)}{1 + \exp(\mu + \alpha_k)}.$$

- Le logarithme de la cote de succès sous le premier niveau du facteur vaut μ .
- Le logarithme du rapport des cotes du succès sous les $k^{\text{èmes}}$ et 1^{er} niveau du facteur vaut $\theta_k - \theta_1 = \alpha_k$.
- Par conséquent une valeur de $\alpha_k > 0$ (< 0) indique que la cote du succès observée est plus grande (petite) sous le $k^{\text{ème}}$ niveau du facteur que sous le 1^{er} niveau.

On estime les α_k à l'aide d'une méthode mathématique appelée maximum de vraisemblance. Dans ce cas, on sait qu'asymptotiquement (lorsque la taille de l'échantillon tend vers l'infini) ces estimateurs suivent une loi normale et sont sans biais.

Par conséquent un intervalle de confiance à 95 % approximatif pour les α_k est :

$$\hat{\alpha}_k \pm 1.96 \cdot \sigma(\hat{\alpha}_k)$$

.

Les différents modèles possibles sont :

- *Modèle 1 avec effet traitement :*

$$\text{logit}(\pi_k) = \theta_k = \mu + \alpha_k$$

- *Modèle 2 sans effet traitement ($\alpha_2 = 0$ ci-dessus) :*

$$\text{logit}(\pi_k) = \theta_k = \mu$$

On compare alors la probabilité de succès estimée dans le groupe k $\tilde{\pi}_k$ et la proportion de succès observée $\hat{\pi}_k$. La déviance D est alors définie ainsi :

$$D = -2 \sum_k \left\{ y_k \log\left(\frac{\tilde{\pi}_k}{\hat{\pi}_k}\right) + (n_k - y_k) \log\left(\frac{1 - \tilde{\pi}_k}{1 - \hat{\pi}_k}\right) \right\} = -2(l(\tilde{\pi}_k) - l(\hat{\pi}_k)).$$

Cette quantité est à rapprocher de la somme des carrés à minimiser dans la régression linéaire simple ou multiple. Elle évalue globalement la qualité de l'ajustement obtenu.

Le deuxième modèle ne fait pas intervenir de variable explicative. Il peut servir à tester la nullité de toutes les pentes : l'équivalent du test de Fisher global dans le cadre de la régression logistique.

On calcule la statistique $G^2 = D_2 - D_1 = -2(l_2 - l_1)$ comparant la déviance des deux modèles.

Sous l'hypothèse H_0 que les restrictions impliquées par le modèle **2** au modèle **1** sont correctes,

$$G \stackrel{H_0}{\sim} \chi^2_{dl_2 - dl_1}$$

Exemple

Sous l'hypothèse nulle

$$H_0 \quad \alpha_2 = 0$$

on a $G_2 = 7.635$ et $dl_1 = 0$, $dl_2 = 1$ ce qui donne une p -valeur de 0.006 et permet de décider que α_2 est significativement différent de 0 au niveau $\alpha = 5\%$. On obtient également les informations suivantes : $\hat{\mu} = 0.38$ et $\hat{\alpha}_2 = 1.97$. Ceci permet de calculer les probabilité de succès : 0.59 et 0.91. Le rapport des cotes de groupe exposé contre le groupe controle est estimé par $\exp(\hat{\alpha}_2) = 7.24$ soit une cote de succès plus de 7 fois plus grande pour le groupe des traités.

On peut construire un intervalle de confiance (approximatif) $(1 - \alpha) \cdot 100\%$ pour le logarithme du rapport de cotes (abrégé en LRC) du groupe k contre le groupe de référence α_k avec

$$\hat{\alpha}_k \pm 1.96\sigma(\hat{\alpha}_k).$$

Exemple

Dans notre exemple on obtient : $\alpha_2 \in (0.36; 3, 58)$ confirmant le rejet de H_0 (avec $\alpha = 0.05$) et l'augmentation significative de développer un cancer du poumon après exposition à la fumée de cigarettes. L'intervalle de confiance approximatif pour le rapport de cote est alors $(1.43, 36.0)$.

Exemple

*Voici un second exemple que l'on va traiter avec Minitab.
Relation entre les habitudes tabagiques d'étudiants en Arizona
et les habitudes de leurs parents (Agresti, 1990, p. 124).*

<i>Nombre de</i>	<i>Enfant</i>	<i>Enfant</i>	
<i>parents fumeurs</i>	<i>fumeur</i>	<i>non fumeur</i>	<i>Total</i>
<i>Deux</i>	<i>400</i>	<i>1380</i>	<i>1780</i>
<i>Un seul</i>	<i>416</i>	<i>1823</i>	<i>2239</i>
<i>Aucun</i>	<i>188</i>	<i>1168</i>	<i>1358</i>

On définit le succès comme étant le fait de fumer pour l'enfant, le modèle logistique précédent devient :

$$\text{logit}(\pi_k) = \theta_k = \mu + \alpha_k; (\alpha_1 = 0).$$

La catégorie de référence est par défaut “Aucun”. On utilise Minitab pour mener à bien l'analyse. On peut tester l'hypothèse

$$H_0 : \alpha_2 = \alpha_3 = 0$$

en comparant la déviance de ce modèle avec celle du précédent. $G_{obs}^2 = 38.37$ d'où une p - de 0.000. Conclusion du test : association significative au niveau $\alpha = 5\%$ entre habitudes tabagiques des parents et des enfants.

Exemple

Effet de la cypermethrine à différentes doses (en μg) sur la survie de parasites. Pour chaque niveau de dose, 20 parasites sont exposés. La survie éventuelle de l'animal est évaluée après 72 heures. Les animaux peuvent être distingués par leur sexe (Collett, 1991, CRC, P. 75).

<i>Dose</i>	<i>N morts</i>	<i>Dose</i>	<i>N morts</i>
<i>Mâle</i>		<i>Femelle</i>	
1	1	1	0
2	4	2	2
4	9	4	6
8	13	8	10
16	18	16	12
32	20	32	16

Variable explicative continue

Ignorons le sexe de l'animal en premier lieu.

Question : Existe-t-il un lien entre la mort d'une larve et la dose reçue ? Si oui quelle est la nature de cette relation ?

- On cherche donc à déterminer comment la probabilité de succès π change avec une ou plusieurs variables explicatives continues à partir des observations de y_i succès en n_i expériences indépendantes sous des valeurs de X observées égales à x_i , ($i = 1, \dots, l$).
- On souhaite utiliser une modélisation de la cote de succès sachant que $X = x$, c'est-à-dire :

$$(Y|X = x_i) \sim \mathcal{B}(n_i, \pi_i)$$

$$\text{logit}(\pi_i) = \theta_i = \theta_i(x_i)$$

Pour avoir une première idée de la relation entre la cote de succès et X , on examine le **logarithme de la cote empirique** contre x_i :

$$\tilde{\theta}_i = \log\left(\frac{y_i + 0.5}{n_i - y_i + 0.5}\right)$$

On s'aperçoit qu'une transformation logarithmique serait la bienvenue.

Le modèle suggéré est donc :

$$(Y|X = x_i) \sim \mathcal{B}(n_i, \pi_i)$$

avec

$$\text{logit}(\pi_i) = \theta_i = \alpha_0 + \beta_1 x_i$$

où $x_i = \log(\text{dose}_i)$.

Régression logistique : variables explicatives mixtes

- Dans l'exemple précédent nous avons ignoré l'influence potentielle du sexe sur la probabilité de succès. L'analyse précédente indique que la dose influe de manière significative sur la probabilité qu'une larve meurt.
- Considérons le cas simple où on a à la fois une variable continue X et une variable qualitative Z . Les données sont donc du type $(y_{ki}, n_{ki}, x_{ki}, z_{ki})$. Le modèle suggéré est donc :

$$(Y|X = x_{ki}, Z = z_{ki}) \sim \mathcal{B}(n_{ki}, \pi_{ki})$$

avec

$$\text{logit}(\pi_{ki}) = \theta_{ki}$$

Nous avons donc 5 modèles à notre disposition :

- $X+Z+X*Z, (\alpha_0 + \alpha_k) + (\beta_1 + \tau_k)x_{ki}.$
- $X+Z, (\alpha_0 + \alpha_k) + \beta_1 x_{ki}.$
- $X, \alpha_0 + \beta_1 x_{ki}.$
- $Z, \alpha_0 + \alpha_k.$
- $1, \alpha_0.$

Reste à détecter les modèles convenables à l'aide du test du G^2 . Pour cela, on utilise Minitab et le fichier de données disponible dans la bibliothèque de documents.